

高分五号高光谱影像的关联对齐域适应与分类

彭江涛¹, 孙伟伟², 魏天慧¹, 范文琦¹

1. 湖北大学 数学与统计学学院, 应用数学湖北省重点实验室, 武汉 430062;

2. 宁波大学 地理与空间信息技术系, 宁波 315211

摘要: 高分五号(GF-5)搭载的高光谱传感器兼顾宽覆盖和高分辨率的特性,但在实际应用中宽覆盖范围内各种地物类别的标注十分困难。当标记样本很少甚至没有标记样本时,遥感图像分类异常困难。此时,可以采用域适应方法,借助已标记的历史数据(源域)实现对未标记数据(目标域)的分类。本文提出了一种基于稀疏矩阵变换的关联对齐域适应分类算法。首先,利用稀疏矩阵变换估计源域和目标域的协方差矩阵;然后,运用协方差关联对齐方法估计源域到目标域的变换矩阵;接着,运用估计得到的变换矩阵将源域数据进行变换,使得其与目标域对齐;最后,在变换后的源域数据上建立分类器,实现对目标域数据的分类。本文的算法在两个真实的GF-5高光谱数据集上进行了验证。实验结果表明,本文算法要优于常用的子空间对齐算法和关联对齐算法。特别地,在黄河口GF-5数据上,本文算法比原始关联对齐方法的最近邻分类准确率提升了3.5%,支持向量机分类准确率提升了2.3%。

关键词: 遥感, 高分五号, 高光谱图像, 域适应, 分类, 关联对齐法, 稀疏矩阵变换

引用格式: 彭江涛,孙伟伟,魏天慧,范文琦.2020.高分五号高光谱影像的关联对齐域适应与分类.遥感学报,24(4): 417-426

Peng J T, Sun W W, Wei T H and Fan W Q. 2020. A modified correlation alignment algorithm for the domain adaptation of GF-5 hyperspectral image. *Journal of Remote Sensing(Chinese)*, 24(4): 417-426[DOI: 10.11834/jrs.20209212]

1 引言

高分五号(GF-5)是世界首颗实现对大气和陆地综合观测的全谱段高光谱卫星(可实现紫外至长波红外谱段的高光谱观测),装载了2台陆地观测载荷和4台大气类观测载荷。这6大载荷使得高分五号卫星可用于大气污染、内陆水体、陆表生态环境、矿物探测等方面,为中国环境监测、资源勘查、防灾减灾等行业,提供高质量、高可靠的高光谱数据。

高分五号卫星上搭载的先进超光谱成像仪(GF5_AHSI)的空间分辨率为30 m,覆盖的地表范围跨度可达几十公里。在如此大的范围内,对各种地物类型和类别的标注显得十分困难。由于采集困难并且人工标记的成本较高,标记样本的数量通常会非常有限。在标记样本有限的情况下,高光谱图

像分类算法模型通常性能较差(Bioucas-Dias等, 2013; 张良培和李家艺, 2016)。如何在标记样本有限甚至无标记样本的情况下,实现大幅度遥感场景地物的自动分类,是一个具有挑战性的课题,同时也具有重要的实际意义(Tuia等, 2016)。由于遥感数据自身的特点,相似的场景或相同的传感器对应的高光谱数据具有相似的特性(童庆禧等, 2016)。因此,可以利用由相似材料覆盖的标记场景或由相同高光谱传感器获取的历史标记图像来对未标记图像进行分类。已有的标记图像可以被视作源域,未标记的图像作为目标域。域适应DA(Domain Adaptation)技术则可利用源域中的标记样本信息来辅助实现对目标域的分类(Tuia等, 2016; Peng等, 2019; Long等, 2013)。

域适应的难点在于:源域和目标域之间总是存在一定的数据偏差,即两个域中的样本服从不

收稿日期: 2019-06-25; 预印本: 2019-12-20

基金项目: 国家自然科学基金(编号: 61871177, 11771130, 41971296, 41671342, U1609203); 浙江省自然科学基金(编号: LR19D010001, LQ18D010001)

第一作者简介: 彭江涛, 1982年生,男,教授,研究方向为高光谱图像处理。E-mail: pengjt1982@hubu.edu.cn

通信作者简介: 孙伟伟, 1985年生,男,教授,研究方向为地理信息系统、遥感理论和方法。E-mail: sunweiwei@nbu.edu.cn

同的分布。对于GF-5数据而言,单幅图像覆盖范围可能为几十公里。对于某一类型地物,它可能分布在同一幅图像中的不同区域。由于地物分布区域不同且不同区域之间间隔可能较远,这会导致对应的光谱曲线发生较大偏移。当源域和目标域之间存在光谱偏移时,源域的信息将无法直接应用于目标域。

为了减少域偏移,可以从不变特征选择、分类器自适应、数据分布自适应等方面开展相关研究。Izquierdo-Verdiguier等(2013)通过数据扩充的方式,模拟支持向量的潜在变化模式,构造具有旋转、反射、尺度不变性质的虚拟支持向量,扩充训练集,从而进行支持向量机分类。Persello和Bruzzone(2016)构造了核空间不变特征,进行高光谱图像迁移学习。分类器自适应方法中常用的一类方法是半监督学习方法,它结合源域的标记样本信息和目标域未标记样本进行分类器设计,如极大似然估计方法(Bruzzone和Prieto, 2001)和主动学习方法(Bruzzone等, 2006)。数据分布自适应方法旨在通过一些变换使得源域和目标域数据分布尽量相似,从而使得源域学习得到的模型能直接应用于目标域。常用的方法为样本重新加权或者子空间变换,如子空间对齐SA(Subspace Alignment)(Fernando等, 2013)、测地流核GFK(Geodesic Flow Kernel)(Gong等, 2012)、迁移成分分析TCA(Transfer Component Analysis)(Pan等, 2011)等。子空间对齐算法首先将源域和目标域分别投影到子空间,然后寻找一个映射将源域子空间和目标域子空间进行对齐。子空间可以运用主成分分析PCA(Principal Component Analysis)求解得到(Fernando等, 2013),也可以通过偏最小二乘PLS(Partial Least Squares)求解得到(Sun等, 2016)。测地流核方法首先将源域和目标域投影到子空间,然后构造一条测地线,使得源域子空间尽量接近目标域子空间。测地线可用来刻画从源域到目标域的几何和统计变化情况(Gong等, 2012)。类似于子空间对齐方法,测地流核方法中子空间也可采用主成分分析或偏最小二乘来学习得到。迁移成分分析将源域和目标域的数据一起映射到一个高维的再生核希尔伯特空间。在此空间中,最小化源域和目标域的数据距离,同时最大程度地保留它们各自的内部属性(Pan等, 2011)。核空间的距离采

用最大均值差异进行度量。

与基于子空间的特征匹配对齐方法不同,关联对齐法CORAL(Correlation alignment)直接针对原始数据进行处理,它通过对齐源域和目标域分布的二阶统计量(协方差)来最小化域移位(Sun等, 2016)。关联对齐法不需要任何目标域样本的标记,易于实现,并且已在高光谱图像域适应上展现了良好的性能(Ma等, 2019)。关联对齐法的计算分为如下两步:(1)计算每个域的数据协方差;(2)对源域特征进行白化(whitening)和重新着色(re-coloring)处理。在步骤(1)中,协方差的计算是关键点。当源域或目标域中的样本数量有限时,计算得到的样本协方差矩阵通常是不准确的(Hoffbeck和Landgrebe, 1996)。另外,步骤(2)中需要对源域中的协方差矩阵求逆,其在样本数量有限的情况下也是不稳定的。

为了解决上述两个问题,本文采用稀疏矩阵变换SMT(Sparse Matrix Transform)方法来估计源域和目标域的协方差(Cao等, 2011; Theiler等, 2011; Cao和Bouman, 2009; Peng和Luo, 2016)。稀疏矩阵变换是由Cao和Bouman(2009)提出的,该方法主要用于估计协方差。Theiler等(2011)将稀疏矩阵变换应用于高光谱图像维数约简、异常检测、变化检测等。Peng和Luo(2016)将稀疏矩阵变换应用于高光谱图像线性判别分析。本文将稀疏矩阵变换应用于域适应,提出基于稀疏矩阵变换的关联对齐方法(CORAL-SMT)来解决高光谱图像无监督域适应与分类问题。在CORAL-SMT中,源域和目标域的协方差矩阵被约束为具有一个特征分解,这个特征分解可以表示为一系列吉文斯(Givens)旋转的乘积形式。在极大似然框架下,基于贪婪最小化策略,可以有效地估计得到协方差,并且估计得到的协方差可以保证是正定的。

2 研究方法

本节首先介绍关联对齐算法、稀疏矩阵变换方法,然后基于稀疏矩阵变换改进关联对齐算法。

2.1 关联对齐法

记源域数据样本集为 $S = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l\}$,对应的标记集合为 $\mathbf{Y}_S = \{y_1, y_2, \dots, y_l\}$,其中 $\mathbf{x}_i \in R^d$, $y_i \in \{1, 2, \dots, c\}$ 。目标域的未标记样本集合表示为

$T = \{\mathbf{x}_{l+1}, \mathbf{x}_{l+2}, \dots, \mathbf{x}_n\}$ 。域适应的目标是利用源域的标记样本信息实现对目标域未标记样本的分类。

假设源域和目标域样本数据均已进行均值中心化预处理, 并记源域和目标域样本所对应的协方差矩阵分别为: $\mathbf{C}_S$ 和 $\mathbf{C}_T$ 。由于源域和目标域数据之间存在一定差异, $\mathbf{C}_S \neq \mathbf{C}_T$ 。关联对齐法的目标是找到一个线性变换矩阵 $\mathbf{A}$, 使得源域数据经过变换之后, 其对应的协方差与目标域协方差相匹配。源域特征 $\mathbf{S}$ 经过线性变换矩阵 $\mathbf{A}$ 变换后, 得到特征 $\mathbf{SA}$, 其对应的协方差矩阵为 $\mathbf{A}^T \mathbf{C}_S \mathbf{A}$ 。关联对齐法优化目标如下

$$\min_{\mathbf{A}} \left(\left\| \mathbf{C}_S - \mathbf{C}_T \right\|_F^2 = \left\| \mathbf{A}^T \mathbf{C}_S \mathbf{A} - \mathbf{C}_T \right\|_F^2 \right) \quad (1)$$

式中, $\mathbf{C}_S = \mathbf{A}^T \mathbf{C}_S \mathbf{A}$ 表示变换后源特征 $\mathbf{SA}$ 的协方差, $\|\cdot\|_F$ 表示矩阵的 Frobenius 范数。

通过求解上述优化目标, 可以得到变换矩阵 $\mathbf{A}$ 具有如下形式 (Sun 等, 2016)

$$\mathbf{A} = \mathbf{C}_S^{-\frac{1}{2}} \mathbf{C}_T^{\frac{1}{2}} \quad (2)$$

可以看出, 源域特征变换可分解为如下两步

$$\mathbf{S} = \mathbf{S} \mathbf{C}_S^{-\frac{1}{2}}, \quad \mathbf{S}^* = \mathbf{S} \mathbf{C}_T^{\frac{1}{2}} \quad (3)$$

式中, 第一步为源域数据自身的白化变换; 第二步, 运用目标域协方差对变换后数据进行重新着色, 从而使得源域和目标域协方差对齐。

2.2 稀疏矩阵变换

给定 N 个样本 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 其中 $\mathbf{x}_i$ 为 d 维空间中的一个点。假设 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ 是具有零均值且独立同分布的高斯随机向量, 其协方差矩阵记为 $\mathbf{R}$ 。样本协方差 $\mathbf{D} = \frac{1}{N} \mathbf{X} \mathbf{X}^T$ 是真实协方差矩阵 $\mathbf{R}$ 的无偏估计, 其中 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ 。为了较好地估计真实协方差矩阵 $\mathbf{R}$, 通常要求样本数量 N 较大。当样本数量较少且维数较高时, 样本协方差矩阵为奇异矩阵, 这使得很多基于协方差的算法性能变差甚至无法运行。为了使得协方差矩阵非奇异, 可采用稀疏矩阵变换 (SMT) 方法估计协方差矩阵 (Cao 等, 2011; Theiler 等, 2011; Cao 和 Bouman, 2009)。

假设协方差矩阵 $\mathbf{R}$ 的特征分解为: $\mathbf{R} = \mathbf{E} \mathbf{\Lambda} \mathbf{E}^T$, 式中, $\mathbf{E}$ 表示正交特征向量矩阵, $\mathbf{\Lambda}$ 表示特征值的对角矩阵。由 $\mathbf{X}$ 的联合极大似然估计可以推导出有关 $\mathbf{E}$ 和 $\mathbf{\Lambda}$ 的结果如下 (Cao 和 Bouman, 2009)

$$\hat{\mathbf{E}} = \arg \min_{\mathbf{E} \in \Omega} \left(\left\| \text{diag}(\mathbf{E}^T \mathbf{D} \mathbf{E}) \right\| \right) \quad (4)$$

$$\hat{\mathbf{\Lambda}} = \text{diag}(\hat{\mathbf{E}}^T \mathbf{D} \hat{\mathbf{E}}) \quad (5)$$

式中, $\text{diag}(\mathbf{A})$ 表示取矩阵 $\mathbf{A}$ 的对角线组成的对角矩阵, $|\mathbf{A}|$ 表示矩阵 $\mathbf{A}$ 的行列式, Ω 是允许的正交变换集合, $\hat{\mathbf{E}}$ 和 $\hat{\mathbf{\Lambda}}$ 分别为估计得到的正交特征向量矩阵和特征值对角矩阵。 $\hat{\mathbf{R}} = \hat{\mathbf{E}} \hat{\mathbf{\Lambda}} \hat{\mathbf{E}}^T$ 是协方差矩阵的极大似然估计。

为了提升正交特征向量矩阵 $\mathbf{E}$ 的极大似然估计精度, Cao 和 Bouman (2009) 提出将 Ω 限制为具有如下特定形式的正交变换集合, 也就是说, 这些正交变换可以表示为一系列吉文斯旋转 (Givens rotations) 的乘积: $\mathbf{E} = \mathbf{E}_1 \mathbf{E}_2 \dots \mathbf{E}_K$ 。其中, 吉文斯旋转 $\mathbf{E}_k$ 是一个围绕两条轴 i_k 和 j_k , 旋转角度为 θ_k 的简单旋转, 其形式为

$$\mathbf{E}_k = \mathbf{I} + \Theta(i_k, j_k, \theta_k) \quad (6)$$

式中, $\mathbf{I}$ 为单位矩阵, 且

$$\Theta(i_k, j_k, \theta_k)_{rs} = \begin{cases} \cos(\theta_k) - 1, & r = s = i_k \text{ 或 } r = s = j_k \\ \sin(\theta_k), & r = i_k \text{ 且 } s = j_k \\ -\sin(\theta_k), & r = j_k \text{ 且 } s = i_k \\ 0, & \text{其他} \end{cases} \quad (7)$$

稀疏矩阵变换方法的目的是通过有限次的吉文斯旋转得到特征向量矩阵的估计。吉文斯旋转完全由坐标 i_k 和 j_k , 以及旋转角度 θ_k 确定。可以使用贪婪最小化方法来求解相关参数。在每次迭代时, 首先通过最小化 $\hat{\mathbf{E}}$ 来确定两个坐标 i_k 和 j_k

$$(i_k, j_k) \leftarrow \arg \min_{(i,j)} \left(1 - \frac{D_{ij}^2}{D_{ii} D_{jj}} \right) \quad (8)$$

一旦确定了 i_k 和 j_k , 吉尔斯旋转 $\hat{\mathbf{E}}_k$ 可由下式得到

$$\hat{\mathbf{E}}_k = \mathbf{I} + \Theta(i_k, j_k, \theta_k) \quad (9)$$

式中, $\theta_k = \frac{1}{2} \arctan \left(-2D_{i_k j_k}, D_{i_k i_k}, -D_{j_k j_k} \right)$ 。

2.3 基于稀疏矩阵变换的关联对齐法

CORAL 算法的目标是对齐源域和目标域的样本协方差, 其中协方差矩阵的计算至关重要。考虑到 SMT 方法的优良性能 (Theiler 等, 2011), 我们提出采用 SMT 方法分别计算源样本和目标样本

的协方差, 如下

$$\hat{C}_S = \hat{E}_S \hat{A}_S \hat{E}_S^T, \hat{C}_T = \hat{E}_T \hat{A}_T \hat{E}_T^T \quad (10)$$

然后, 将计算得到的协方差矩阵进行对齐

$$\min_A \left\| A^T \hat{C}_S A - \hat{C}_T \right\|_F^2 \quad (11)$$

最终计算得到的线性变换矩阵为

$$A = \hat{C}_S^{-\frac{1}{2}} \hat{C}_T^{\frac{1}{2}} \quad (12)$$

算法1展示了我们提出的基于稀疏矩阵变换的关联对齐算法 (CORAL-SMT)。

算法1 CORAL-SMT算法

输入: 源数据 S , 目标数据 T , 源标记 Y_S

1 通过SMT估计协方差:

$$\hat{C}_S = \hat{E}_S \hat{A}_S \hat{E}_S^T$$

$$\hat{C}_T = \hat{E}_T \hat{A}_T \hat{E}_T^T$$

2 求解变换矩阵:

$$A = \hat{C}_S^{-\frac{1}{2}} \hat{C}_T^{\frac{1}{2}}$$

3 源域对齐

$$\hat{S} = S * A$$

4 目标域分类


$$\hat{Y}_T = \text{classifier}(\hat{S}, Y_S, T)$$

输出: 目标域的数据类别 $\hat{Y}_T$

3 实验结果


3.1 实验数据

(1) 黄河口 GF-5 数据集: 利用 GF-5 AHSI 传感器于 2019-01-07 获取的黄河口地区的高光谱分辨率影像。影像大小为 1185×1342。传感器的空间分辨率为 30 m, 光谱分辨率为: VNIR (可见光与近红外): 4.278—4.460 nm, SWIR (短波红外): 8.420—8.450 nm。成像光谱范围为 VNIR: 0.390—1.029 μm; SWIR: 1.005—2.513 μm; 包含 330 个波段, 其中 VNIR 150 个波段, SWIR 180 个波段。剔除 45 个坏波段, 余下 285 个波段用于分类。通过地物类别实地调研, 该影像共标注地物类别 21 类, 主要以湿地、水草、农作物为主。为了验证领域自适应算法性能, 模拟有偏差采样的情形, 即构造互不相交的源域和目标域。具体地, 将数据集等分为两个互不相交的区域, 如图 1 所示, 红线上方为源域, 下方为目标域。在源域和目标域中挑选 5 类样本用于迁移学习, 具体信息见表 1, 其中源域和目标域样本总数分别为 1325 和 1948。



(a) 伪彩色合成图像

(a) RGB composite image



(b) 类别标记图

(b) Ground truth

图1 黄河口 GF-5 数据的伪彩色合成图像(图(a)波段 1, 30, 20 分别设定为红、绿、蓝分量)和选定的 5 类样本标记图
Fig. 1 RGB composite image for the Huanghekou GF-5 data (Fig. 1(a), bands 1, 30, 20 are set as the red, green, blue components) and the ground-truth of five classes

表1 黄河口数据源域和目标域样本数目

Table 1 The number of samples in the source and target domains of Huanghekou data

编号	类别	源域	目标域	颜色
1	盐沼	132	261	红色
2	水产养殖区	453	343	绿色
3	池塘	430	506	蓝色
4	建成区	134	419	紫色
5	大豆	176	419	青色

(2) 盐城 GF-5 数据集: 利用 GF5_AHSI 传感器于 2019-04-04 获取的江苏盐城地区的高光谱分辨率影像。影像大小为 1175×585。成像区域中心的经纬度分别为 120.177876°E 和 34.270704°N。传感器的空间分辨率为 30 m。总共含 330 个波段, 剔

除 63 个坏波段，余下 267 个波段用于分类。该影像对应盐城滨海湿地，通过地物类别实地调研，该影像共标注地物类别 20 类，包括浅海、海滩、池塘、沼泽、树林、裸土等。将数据集分为两个互不相交的区域，从而模拟有偏差采样的情形，如图 2 所示，红线下方为源域，上方为目标域。在源域和目标域中挑选 6 类样本用于迁移学习，具体信息见表 2，其中源域和目标域样本总数分别为 1140 和 1880。




图2 盐城 GF-5 数据的伪彩色合成图像(图(a)波段 1, 30, 20 分别设定为红、绿、蓝分量)和选定的 6 类样本标记图
Fig. 2 RGB composite image for the Yancheng GF-5 data (Fig. 2(a) bands 1, 30, 20 are set as the red, green, blue components) and the ground-truth of six classes

表 2 盐城数据源域和目标域样本数目
Table 2 The number of samples in the source and target domains of Yancheng data

编号	类别	源域	目标域	颜色
1	浅海	365	940	Red
2	水产养殖区	76	152	Green
3	稻田	427	405	Blue
4	河流	137	80	Purple
5	休耕地	53	181	Cyan
6	旱地	82	122	Yellow

3.2 对比算法

本文所提出的基于稀疏矩阵变换的关联对齐算法 (CORAL-SMT) 与下面算法进行对比:

(1) NA (No Adaptation): 直接用源域学习

得到的模型去分类目标域样本。

(2) PCA (Principal Component Analysis): 利用主成分分析方法学习源域和目标域样本的共同子空间。

(3) SA (Subspace Alignment): 子空间对齐算法 (Fernando 等, 2013), 通过 PCA 变换构造源域和目标域子空间, 然后将子空间进行对齐。

(4) TCA (Transfer Component Analysis): 迁移成分分析方法 (Pan 等, 2011), 它将源域和目标域数据一起映射到一个高维再生核希尔伯特空间, 并在此空间中最小化源域和目标域的平均距离。实验中, 采用线性核函数。

(5) GFK (Geodesic Flow Kernel): 测地线核方法 (Gong 等, 2012), 首先将源域和目标域分别投影到子空间, 然后构造一条从源域子空间到目标域子空间的一条测地线, 使得源域靠近目标域。

(6) ITL (Information-Theoretical Learning): 信息理论学习方法 (Shi 和 Sha, 2012), 学习域不变特征空间的同时优化目标域上判别分类相关的信息理论度量。

(7) CORAL (CORrelation Alignment): 关联对齐算法 (Sun 等, 2016), 对齐源域和目标域的协方差。

当上述算法将源域和目标域对齐之后, 采用最近邻 NN (Nearest Neighbor) 和支持向量机 SVM (Support Vector Machine) 分类器对目标域样本进行分类。SVM 中采用线性核函数, 其中惩罚参数 C 的调节范围为 $\{1, 10, 100, 1000, 10000\}$ 。分类性能评价指标为总体分类准确率 OA (Overall Accuracy) 和 κ 系数。

3.4 实验结果

3.4.1 黄河口数据实验结果

分类的总体准确率和 κ 系数, 如表 3 所示。从实验结果可以看出:

(1) NA 可以得到较高分类精度。这表明, 采用源域数据训练得到的模型直接对目标域进行分类, 亦可达到较为满意的分类精度。GF-5 数据的光谱分辨率很高, 它能够刻画物质的本质光谱特征。在有偏差采样的情况下, 高分辨率的光谱数据仍然能够鉴别物质内在的不变特征。

表3 黄河口数据分类结果

Table 3 Classification results on the Huanghekou data

	NN		SVM	
	OA	κ	OA	κ
NA	0.9204	0.8988	0.9127	0.8887
PCA	0.8470	0.8046	0.8701	0.8338
SA	0.8655	0.8282	0.9091	0.8840
TCA	0.6971	0.6175	0.8106	0.7568
GFK	0.8711	0.8355	0.9086	0.8834
ITL	0.9107	0.8866	0.8989	0.8712
CORAL	0.9271	0.9072	0.9204	0.8984
CORAL-SMT	0.9620	0.9518	0.9435	0.9282

注:黑体表示准确率最高值。

(2) 传统的基于子空间的对齐算法,如PCA, SA, TCA, GFK, 对此数据基本失效。经过这些子空间对齐算法处理之后,分类性能反而不如NA直接分类。子空间对齐算法中子空间的学习至关重要。当学习得到的子空间不准确,或者子空间出现关键信息损失时,子空间对齐算法反而会起到负面作用,导致分类性能变差。

(3) CORAL算法直接将源域和目标域协方差进行对齐,能够在一定程度上改进原始的NA。我们提出的改进的CORAL-SMT,通过改进协方差估计,得到更加准确可靠的协方差矩阵,从而能够

取得更好的效果。这表明选择合适的域适应算法,还是能够极大提升分类性能。但是,注意到CORAL-SMT中,需迭代求解协方差矩阵,计算速度比CORAL要慢,CORAL和CORAL-SMT分别耗时0.1 s和9.5 s。

为了从视觉上直观地呈现NA, CORAL, CORAL-SMT算法的差异,本文分别将原始数据以及CORAL和CORAL-SMT变换之后的源域和目标域样本,采用PCA变换投影到2维空间,展示相应图形如图3所示。从图3 (a),可以明显看出:原始数据上源域和目标域之间存在一个较为明显的分布漂移情况。源域数据靠近图形下方,而目标域分布在图形上方。尽管NA算法能够产生较高分类准确率,仍然有必要通过域适应将源域和目标域数据进行对齐,消除这种分布偏差,从而进一步提升分类性能。图3 (b)中,通过CORAL变换,源域和目标域数据之间更加接近,但是红色和蓝色部分有大量重叠。从图3 (c)可以看出,经过SMT变换之后,源域和目标域对应的同类样本之间更加紧密。特别地,红色部分有向左上角收缩的趋势、绿色部分向下方收缩、蓝色部分向右收缩。这表明,SMT变换之后,估计得到的协方差更加准确,每类样本对应的方差和变化范围更加准确,从而使得对齐之后的结果更加可靠。




图3 黄河口数据源域和目标域2维散点图

Fig. 3 Two dimentional scatterplots of Huanghekou source and target data

将NA, CORAL, CORAL-SMT在各类上的分类结果进行详细比较。表4—表6分别给出了NA, CORAL, CORAL-SMT方法的分类混淆矩阵(Confusion Matrix)。可以发现,NA中,错分主要出现在第1类和第4类,其中,第1类(红色)错

分到第2类(绿色)和第3类(蓝色)、第4类(紫色)错分到第5类(青色)。第1类为湿地,第2类为水产养殖区,第3类为池塘,这3类都与水有关系,光谱上具有一定相似性,因此难以完全区分。经过CORAL变换之后,第1类只错分到第3类,

另外，紫色分到青色的错分也得到了一定的缓解。经过CORAL-SMT处理之后，已基本上能将紫色和青色分开。红色部分的错分也得到了极大减少。

表 4 黄河口数据上NA方法的分类混淆矩阵
Table 4 Classification confusion matrix of NA on the Huanghekou data

		NA 预测结果				
		1	2	3	4	5
真实类别	1	173	11	77	0	0
	2	0	342	1	0	0
	3	0	4	502	0	0
	4	0	0	0	357	62
	5	0	0	0	0	419

表 5 黄河口数据上CORAL方法的分类混淆矩阵
Table 5 Classification confusion matrix of CORAL on the Huanghekou data

		CORAL 预测结果				
		1	2	3	4	5
真实类别	1	169	0	92	0	0
	2	0	343	0	0	0
	3	2	11	493	0	0
	4	0	0	0	382	37
	5	0	0	0	0	419

表 6 黄河口数据上CORAL-SMT方法的分类混淆矩阵
Table 6 Classification confusion matrix of CORAL-SMT on the Huanghekou data

		CORAL-SMT 预测结果				
		1	2	3	4	5
真实类别	1	203	15	43	0	0
	2	0	343	0	0	0
	3	0	3	503	0	0
	4	0	0	0	408	11
	5	0	0	0	2	417

3.4.2 盐城数据实验结果

我们将域适应算法应用于盐城数据上，采用NN和SVM进行分类，得到的总体准确率和 κ 系数，如表7所示。从实验结果可以看出：

- (1) 类似于黄河口数据，NA仍可以得到较高分类精度。
- (2) 基于子空间的对齐算法，如PCA，SA，GFK，能够在一定程度上改进NA结果。但是TCA对此数据基本失效。另外，ITL方法性能也很差。

表 7 盐城数据分类结果
Table 7 Classification results on the Yancheng data

	NN		SVM	
	OA	κ	OA	κ
NA	0.9059	0.8623	0.9213	0.8875
PCA	0.9053	0.8608	0.9261	0.8916
SA	0.9064	0.8620	0.9239	0.8832
TCA	0.7548	0.6635	0.8676	0.8117
GFK	0.9059	0.8612	0.9346	0.9038
ITL	0.8335	0.7706	0.8340	0.7702
CORAL	0.9543	0.9328	0.9484	0.9248
CORAL-SMT	0.9559	0.9352	0.9532	0.9315

注：黑体表示准确率最高值。

(3) CORAL算法显著地改善了原始的NA。我们提出改进的CORAL-SMT，稍微改进了原始的CORAL算法，得到了最高的总体准确率和 κ 系数。

(4) 在此数据上，除了CORAL和CORAL-SMT之外，SVM通常比NN效果更好。但在CORAL上，NN效果稍好。在CORAL-SMT上，NN和SVM效果相当。

原始数据以及CORAL和CORAL-SMT变换之后的源域和目标域样本，采用PCA变换投影到2维空间，对应图形如图4所示。图中仍然可以看出，来自不同地理位置的源域与目标域之间存在明显的分布偏差。域适应算法，如CORAL和CORAL-SMT，能够在一定程度上改进这种分布漂移。CORAL-SMT对CORAL最明显的一个改进主要在于黑色部分。经过CORAL-SMT处理之后，黑色部分对应的源域和目标域样本之间更加接近了。

表8和表9分别给出了NA和CORAL-SMT方法的分类混淆矩阵（Confusion Matrix）。从表8可以看出，NA方法主要将第2类（绿色）错分到第4类（紫色）、第5类（青色）错分到第6类（黑色）。从图4（a）也可明显看出绿色与紫色混叠、青色与黑色混叠。第2类为水产养殖区，第4类为河流，这两类具有一定相似性。第5、6类分别为空地 and 干土地，具有相似的属性，也难以区分。经过CORAL-SMT变换之后，第2类和第5类的错分率得到了极大的下降。另外，可以发现，基于协方差的CORAL-SMT算法在样本数目较多的类别通常能够产生较好的结果。当某类样本较多时，对应的协方差估计更加准确。




图4 盐城数据源域和目标域二维散点图

Fig. 4 Two dimensional Scatterplots of Yancheng source and target data

表8 盐城数据上NA方法的分类混淆矩阵

Table 8 Classification confusion matrix of NA on the Yancheng data

	NA 预测结果					
	1	2	3	4	5	6
真实类别	1	940	0	0	0	0
	2	0	81	0	71	0
	3	0	0	405	0	0
	4	0	12	4	57	7
	5	0	0	1	0	101
	6	0	0	0	0	3

表9 盐城数据上CORAL-SMT方法的分类混淆矩阵

Table 9 Classification confusion matrix of CORAL-SMT on the Yancheng data

	CORAL-SMT 预测结果					
	1	2	3	4	5	6
真实类别	1	939	0	0	1	0
	2	0	121	0	29	2
	3	0	0	405	0	0
	4	0	0	10	59	11
	5	0	0	4	0	159
	6	0	0	1	0	7

4 结 论

本文提出了一种基于稀疏矩阵变换的关联对齐域适应算法。该方法首先采用稀疏矩阵变换技术学习得到源域和目标域对应的协方差矩阵,然后采用关联对齐方法,学习得到一个线性变换矩阵,将源域和目标域协方差进行对齐。所提出的

算法在黄河口和盐城湿地 GF-5 高光谱数据上进行了验证。实验结果表明, GF-5 高光谱数据具有较好的光谱鉴别能力,即使直接采用源域模型分类目标域样本,亦能得到较为满意的分类结果。但是。尽管如此,从数据分布图仍可明显看出来自不同区域的属于同一类别的 GF-5 高光谱数据之间存在分布偏差。本文提出的基于稀疏矩阵变换的关联对齐域适应算法,能够得到较为准确的协方差矩阵估计,改进了原始的关联协方差对齐算法,可更有效地减少因采样偏差所导致的不同域之间的分布差异。然而,由于稀疏矩阵变换需迭代更新求解吉文斯旋转矩阵,算法计算复杂度更高。下一步将探讨如何快速找到更为有效的吉文斯旋转矩阵,并将稀疏矩阵变换技巧应用于其他域适应算法。

参考文献 (References)

- Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N, and Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. IEEE Geoscience and Remote Sensing Magazine, 1(2): 6-36 [DOI: 10.1109/MGRS.2013.2244672]
- Bruzzone L, Chi M and Marconcini M. 2006. A novel transductive SVM for semisupervised classification of remote-sensing images. IEEE Transactions on Geoscience and Remote Sensing, 44(11): 3363-3373 [DOI: 10.1109/TGRS.2006.877950]
- Bruzzone L and Prieto D F. 2001. Unsupervised retraining of a maximum-likelihood classifier for the analysis of multitemporal remote-sensing images. IEEE Transactions on Geoscience and Remote Sensing, 39(2): 456-460 [DOI: 10.1109/36.905255]
- Cao G Z, Bachega L R and Bouman C A. 2011. The sparse matrix transform for covariance estimation and analysis of high dimensional signals. IEEE Transactions on Image Processing, 20(3): 625-640

- [DOI: 10.1109/TIP.2010.2071390]
- Cao G Z and Bouman C A. 2009. Covariance estimation for high dimensional data vectors using the sparsematrix transform//Proceedings of the 21st International Conference on Neural Information Processing Systems. Red Hook, NY. NIPS.; ACM:225-232
- Fernando B, Habrard A, Sebban M and Tuytelaars T. 2013. Unsupervised visual domain adaptation using subspace alignment//Proceedings of 2013 IEEE International Conference on Computer Vision, ICCV. Sydney, NSW, Australia: IEEE:2960-2967 [DOI: 10.1109/ICCV.2013.368]
- Gong B Q, Shi Y, Sha F and Grauman K. 2012. Geodesic flow kernel for unsupervised domain adaptation//Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI, USA, CVPR.; IEEE:2066-2073 [DOI: 10.1109/CVPR.2012.6247911]
- Hoffbeck J P and Landgrebe D A. 1996. Covariance matrix estimation and classification with limited training data. IEEE Transactions on Pattern Analysis and Machine Intelligence, 18(7): 763-767 [DOI: 10.1109/34.506799]
- Izquierdo-Verdiguier E, Laparra V, Gómez-Chova L and Camps-Valls G. 2013. Encoding invariances in remote sensing image classification with SVM. IEEE Geoscience and Remote Sensing Letters, 10(5): 981-985 [DOI: 10.1109/LGRS.2012.2227297]
- Long M S, Wang J M, Ding G G, Sun J G and Yu P S. 2013. Transfer feature learning with joint distribution adaptation//Proceedings of 2013 IEEE International Conference on Computer Vision. Sydney, NSW, Australia, ICCV: IEEE:2200-2207 [DOI: 10.1109/ICCV.2013.274]
- Ma L, Crawford M M, Zhu L and Liu Y. 2019. Centroid and covariance alignment-based domain adaptation for unsupervised classification of remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, 57(4): 2305-2323 [DOI: 10.1109/TGRS.2018.2872850]
- Pan S J, Tsang I W, Kwok J T and Yang Q. 2011. Domain adaptation via transfer component analysis. IEEE Transactions on Neural Networks, 22(2): 199-210 [DOI: 10.1109/TNN.2010.2091281]
- Peng J T and Luo T. 2016. Sparse matrix transform-based linear discriminant analysis for hyperspectral image classification. Signal, Image and Video Processing, 10(4): 761-768 [DOI: 10.1007/s11760-015-0808-y]
- Peng J T, Sun W W, Ma L and Du Q. 2019. Discriminative transfer joint matching for domain adaptation in hyperspectral image classification. IEEE Geoscience and Remote Sensing Letters, 16(6): 972-976 [DOI: 10.1109/LGRS.2018.2889789]
- Persello C and Bruzzone L. 2016. Kernel-based domain -invariant feature selection in hyperspectral images for transfer learning. IEEE Transactions on Geoscience and Remote Sensing, 54(5): 2615-2626 [DOI: 10.1109/TGRS.2015.2503885]
- Shi Y and Sha F. 2012. Information-theoretical learning of discriminative clusters for unsupervised domain adaptation//Proceedings of the 29th International Conference on International Conference on Machine Learning. Madison, WI, ICML, USA: ACM: 1275-1282.
- Sun B C, Feng J S and Saenko K. 2016. Return of, frustratingly easy domain adaptation//Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence (AAAI-16), Phoenix Convention Center, Phoenix, Arizona, USA: IEEE: 2058-2065
- Sun H, Liu S, Zhou S L, and Zou H X. 2016. Unsupervised cross-view semantic transfer for remote sensing image classification. IEEE Geoscience and Remote Sensing Letters, 13(1): 13-17 [DOI: 10.1109/LGRS.2015.2491605]
- Theiler J, Cao G Z, Bachega L R and Bouman C A. 2011. Sparse matrix transform for hyperspectral image processing. IEEE Journal of Selected Topics in Signal Processing, 5(3): 424-437 [DOI: 10.1109/JSTSP.2010.2103924]
- Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. Journal of Remote Sensing, 20(5): 689-707 (童庆禧, 张兵, 张立福, 2016. 中国高光谱遥感的前沿进展. 遥感学报, 20(5): 689-707) [DOI: 10.11834/jrs.20166264]
- Tuia D, Persello C and Bruzzone L. 2016. Domain adaptation for the classification of remote sensing data: an overview of recent advances. IEEE Geoscience and Remote Sensing Magazine, 4(2): 41-57 [DOI: 10.1109/MGRS.2016.2548504]
- Zhang L P and Li J Y. 2016. Development and prospect of sparse representation-based hyperspectral image processing and analysis. Journal of Remote Sensing, 20(5): 1091-1101. (张良培, 李家艺. 2016. 高光谱图像稀疏信息处理综述与展望. 遥感学报, 20(5): 1091-1101) [DOI: 10.11834/jrs.20166050]

A modified correlation alignment algorithm for the domain adaptation of GF-5 hyperspectral image

PENG Jiangtao¹, SUN Weiwei², WEI Tianhui¹, FAN Wenqi¹

1. Hubei Key Laboratory of Applied Mathematics, Faculty of Mathematics and Statistics, Hubei University, Wuhan 430062, China;

2. Department of Geography and Spatial Information Techniques, Ningbo University, 818 Fenghua Road, Ningbo 315211, China

Abstract: GF-5 is the first full-spectrum hyperspectral satellite used to achieve comprehensive observations of the atmosphere and land.

The hyperspectral sensors on the GF-5 have high spectral resolution and wide coverage. However, labeling all the materials on these wide ranges is extremely difficult in practical applications. Hyperspectral classification is extremely difficult when the number of labeled samples is limited or no labeled sample is available. In this study, we aim to present an effective unsupervised domain adaptation technique that uses labeled pixels in the existing old domain (source domain) to classify the scenes with limited or no labeled pixels (target domain).

Correlation alignment (CORAL) is a simple and effective domain adaptation method. However, the covariance computation in CORAL may be inaccurate in the case of limited training samples. We propose a new CORAL algorithm on the basis of a sparse matrix transform technique (CORAL-SMT) to solve this problem. The proposed method first uses the sparse matrix transform technique to estimate the covariance matrices of the source and target domains and then performs the CORAL between the estimated covariance matrices. The SMT method can obtain an accurate covariance estimator, which is constantly positive and definite.

In the experiment, we compare the proposed CORAL-SMT with some classical domain adaptation methods, such as subspace alignment, principal component analysis, CORAL, transfer component analysis, geodesic flow kernel, and information theoretic learning. After domain adaptation, we use the nearest neighbor and support vector machine as classifiers to classify the unlabeled data in the target domain. Two GF-5 hyperspectral datasets, namely, Huanghekou and Yancheng datasets, are used to evaluate the performance of different methods. Experimental results demonstrate the effectiveness of the proposed method compared with subspace-based alignment methods and CORAL.

The GF-5 data have good spectral discriminative ability. In the case of bias sampling, the performance of classifying the target samples on the basis of the source model is acceptable. The distribution difference between source and target domains is decreased, and the classification performance is intensively improved using the domain adaptation technique. The SMT technique can improve the covariance estimation, thereby benefiting the following domain adaptation.

Key words: remote sensing, GF-5 satellite, hyperspectral image, domain adaptation, classification, correlation alignment, sparse matrix transform

Supported by National Natural Science Foundation of China (No. 61871177, 11771130, 41971296, 41671342, U1609203); Zhejiang Provincial Natural Science Foundation of China (No. LR19D010001, LQ18D010001)